المحاضرة الثانية: التعلم الآلي

(Machine Learning)

تجاوز الذكاء الاصطناعي اليوم الحوسبة الكمومية بكثير في الدراسة النوعية والتنبؤية والانتقائية للبيانات. ويعود ذلك إلى توافر موارد حوسبة هائلة بسهولة للعامة. ويستغل المطورون هذه الموارد الآن لإنشاء نماذج جديدة للتعلم الآلي، ولتحسين النماذج الحالية لتحسين الأداء والنتائج. وقد أدى توافر الحوسبة عالية الأداء بسهولة إلى زيادة مفاجئة في الطلب على مهارات التعلم الآلي والذكاء الاصطناعي بين متخصصي تكنولوجيا المعلومات.

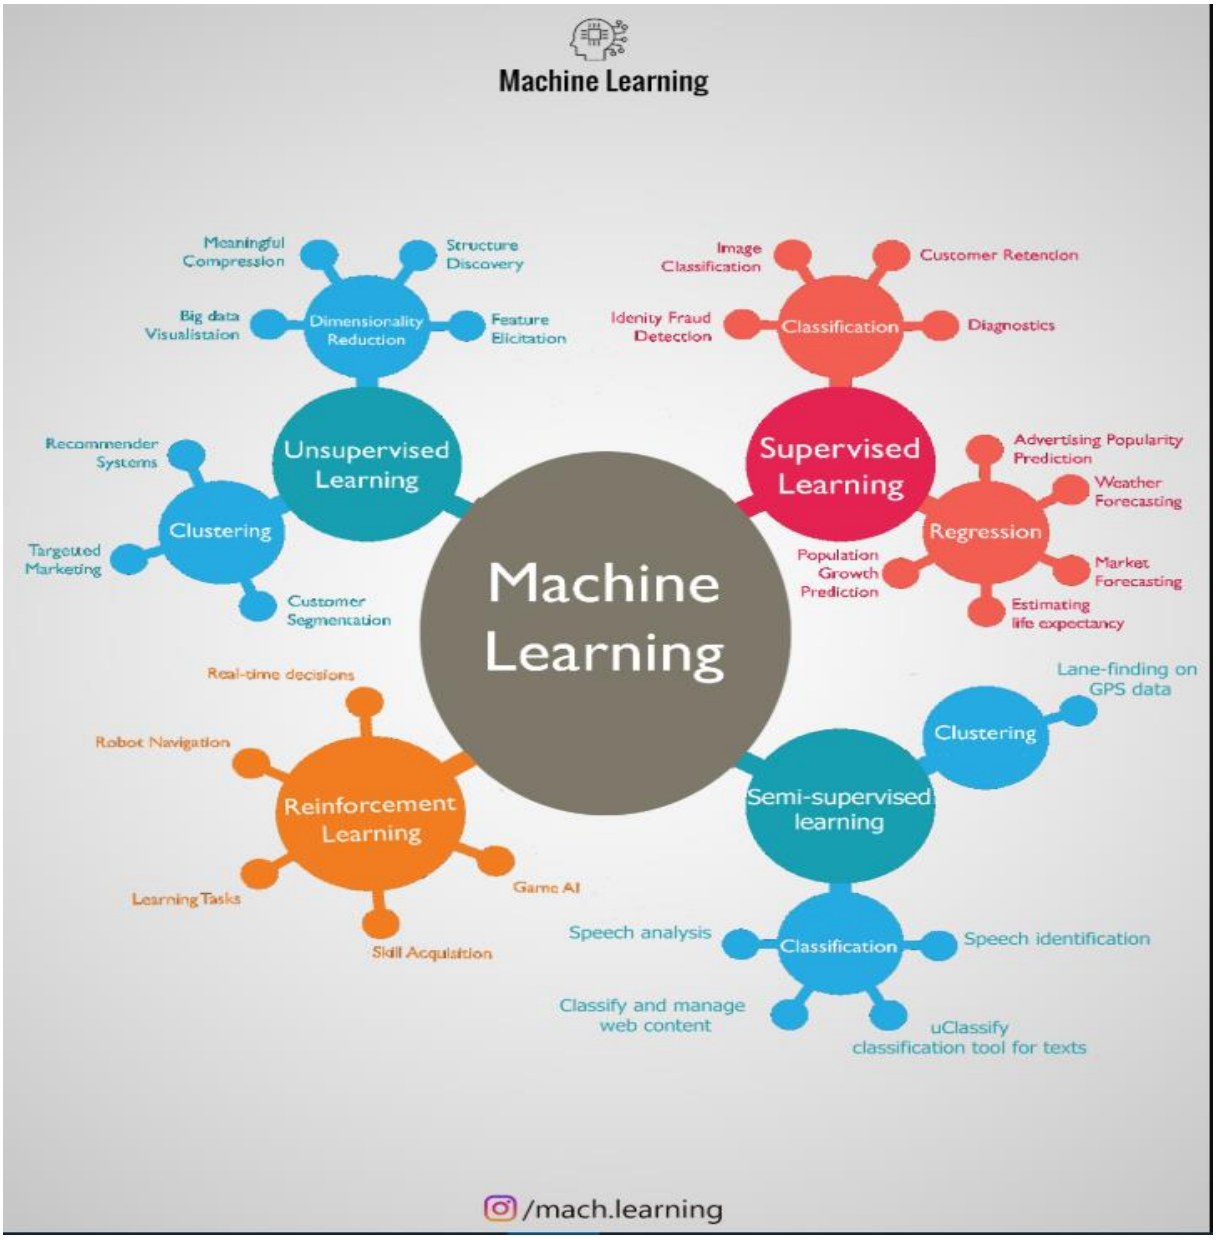

1- مفاهيم حول التعلم الآلي

يُعدّ التعلم الآلي مجالًا فرعيًا من علوم الحاسوب، انبثق من دراسة التعرف على الأنماط ونظرية التعلم الحاسوبي في الذكاء الاصطناعي.

- قدّم آرثر صموئيل مفهوم التعلم الآلي لأول مرة عام ١٩٥٩، بتعريفه التالي: "مجال دراسي يُمكّن أجهزة الحاسوب من التعلم دون الحاجة إلى برمجة صريحة". يُركز هذا التعريف بوضوح على مفهوم الذكاء الاصطناعي، الذي يُمثل البيئة التي تطور فيها التعلم الآلي.
- التعلم الآلي (ML) هو مجال علمي، وتحديدًا فئة فرعية من الذكاء الاصطناعي، يُمكّن أجهزة الحاسوب من اكتساب قدرات التعلم الذاتي دون الحاجة إلى برمجة صريحة. ويشمل أساليب مُختلفة لإنشاء نماذج تلقائيًا من البيانات. تتخذ هذه الأساليب شكل خوارزميات مُصممة لتحليل البيانات وتفسيرها، مما يُسهّل التعلم الذاتي لأنظمة الحاسوب. يستخدم التعلم الآلي خوارزميات لإنشاء نماذج إحصائية من البيانات المُهيكلة.
- يستكشف التعلم الآلي بناء ودراسة الخوارزميات القادرة على التعلم والتنبؤ بالبيانات. تعمل هذه الخوارزميات من خلال بناء نموذج من مُدخلات العينة للتنبؤ أو اتخاذ قرارات بناءً على البيانات، بدلاً من اتباع تعليمات برمجية ثابتة أو ديناميكية بحتة.
- يرتبط التعلم الآلي ارتباطًا وثيقًا بالإحصاءات الحاسوبية، وغالبًا ما يتداخل معها، وهو تخصص يتخصص أيضًا في التحليل والتنبؤ. كما يرتبط ارتباطًا وثيقًا بالتحسين الرياضي، الذي يوفر أساليب ونظريات ومجالات تطبيق لنماذج التعلم الآلي.
- يُستخدم التعلم الآلي في مجموعة من مهام الحوسبة حيث يكون تصميم وبرمجة الخوارزميات الصريحة غير عملي.
- تشمل أمثلة التطبيقات العديد من مجالات علوم البيانات، بما في ذلك تحليل البيانات مثل التصفية، والتعرف الضوئي على الحروف (OCR)، ومحركات البحث، والرؤية الحاسوبية. يُخلط أحيانًا بين التعلم الآلي واستخراج البيانات، على الرغم من أن تركيزه ينصب بشكل أكبر على تحليل البيانات الاستكشافي، ويمكن اعتبارهما وجهين لنفس المجال.
- عند استخدامها في السياقات الصناعية، يمكن الإشارة إلى أساليب التعلم الآلي باسم التحليلات التنبؤية أو النمذجة التنبؤية.

2- أهداف التَعَلم الآلي

- يهدف التعلم الآلي في المقام الأول إلى تطوير نماذج قادرة على تدريب نفسها على التحسين، وإدراك الأنماط المعقدة، وإيجاد حلول للمشكلات الجديدة باستخدام بيانات من نماذج سابقة.
- يُستخدم التعلم الآلي على نطاق واسع في علم البيانات وتحليلها. فهو يُتيح القدرة على تصميم واختبار وتنفيذ خوارزميات التحليل التنبؤي على بيانات متنوعة لتوقع المستقبل. يتضمن ذلك منح الخوارزميات القدرة على اكتشاف "الأنماط"، أي الأنماط المتكررة، في مجموعات البيانات.
- يهدف التعلم الآلي في المقام الأول إلى منح الآلات القدرة على التعلم من البيانات، وتحديد الأنماط وتعميمها لاتخاذ القرارات أو التنبؤ ببيانات جديدة. غالبًا ما يتضمن ذلك خوارزميات تعلم مُشرفة أو غير مُشرفة، والتي تستخدم مجموعات بيانات ضخمة لتدريب نماذج قادرة على تقديم تنبؤات دقيقة أو تقديم رؤى مهمة.

3- أنظمة التعلم الآلي

يمكن تحديد أربعة أنواع رئيسية من أنظمة التعلم الآلي:

I. التعلم الآلي الخاضع للإشراف أو التعلم المر اقب أو التعلم المُوجه (supervised Learning)

يُشبه التعلم الخاضع للإشراف أو المُراقَب تدريب طفل على المشي. تُمسك بيد الطفل، وتُريه كيفية تحريك قدمه للأمام، ثم تُقدّم له عرضًا توضيحيًا للمشي، وهكذا، حتى يتعلم الطفل المشي بمفرده.

هو النوع الأكثر شيوعًا، في هذا النوع، تقوم البيانات المصنفة بتعليم الخوارزمية الاستنتاجات التي يجب أن تتوصل إليها. تمامًا كما يتعلم الطفل التعرف على الفواكه عن طريق حفظها في كتاب مصور، في التعلم الخاضع للإشراف، يتم تدريب الخوارزمية بواسطة مجموعة بيانات مصنفة بالفعل. مثال على التعلم الآلي الخاضع للإشراف هو مرشح البريد الإلكتروني العشوائي، حيث يتم تدريب الخوارزمية على مجموعة بيانات مصنفة يتم فيها وضع علامة على كل بريد إلكتروني إما كبريد عشوائي أو غير عشوائي. يتعلم النموذج من هذه الأمثلة المصنفة ثم يمكنه التنبؤ بما إذا كانت رسائل البريد الإلكتروني الواردة الجديدة من المحتمل أن تكون بريدًا عشوائيًا أم لا بناءً على الأنماط التي حددها. يتطلب هذا النوع من التعلم الخاضع للإشراف خبيرًا بشريًا لتقديم الإجابات الصحيحة عن طريق تصنيف البيانات حتى تتمكن الخوارزمية من التعلم وتقديم تنبؤات دقيقة في المستقبل.

لاحظ أن الهدف هنا ليس التدريب باستخدام بيانات مثالية أو خالية من العيوب تمامًا. أنت تريد محاكاة ما سيراه النظام في العالم الحقيقي - بعض البريد العشوائي يسهل اكتشافه، ولكن الأمثلة الأخرى مُخفاة أو

يصعب تحديدها. تؤدي البيانات النظيفة بشكل مفرط إلى فرط التوافق، ما يعني أن النموذج سيحدد فقط العينات النقية الأخرى.

المبدأ: مع مجموعة من البيانات المُسمّاة (étiquetées)

$$S = \{\langle xi, yi\rangle, i = 1, \cdots, n\},$$

تعلم وظيفة تربط البيانات بالعلامات (les données aux étiquettes):

$$X \, s \, x \longrightarrow y \in Y$$

- $Y \equiv R$: مسألة انحدار
- $Y \equiv$ مجموعة منفصلة (مثل{ 0، 1}): مسألة تصنيف (classification)
- يمكن أن تتوافق F مع فضاء من الدوال الخطية أو غير الخطية

وبالمثل، في التعلم الخاضع للإشراف، تُعطى الحاسوب أمثلة ملموسة معروفة. تقول إنه لقيمة خاصية مُعينة$x1$ ، يكون الناتج$y1$ ، ولـ $x2$ يكون$y2$ ، ولـ $x3$ يكون$y3$ ، وهكذا.

بناءً على هذه البيانات، تُتيح للحاسوب تحديد علاقة تجريبية بين x و yمن خلال حسابات رياضية أو منطقية أو إحصائية.

بمجرد تدريب الآلة بهذه الطريقة باستخدام عدد كافٍ من نقاط البيانات، ستطلب منها الآن التنبؤ بقيمة Yلقيمة X مُعينة. بافتراض أنك تعرف القيمة الفعلية لـ Y لقيمة X المُعينة، يُمكنك حينها استنتاج ما إذا كان تنبؤ الآلة صحيحًا.

هكذا يُمكننا اختبار ما إذا كانت الآلة قد تعلمت باستخدام بيانات الاختبار المعروفة. بمجرد التأكد من قدرة الآلة على التنبؤ بدقة عالية (مثلاً 80-90%)، يمكنك إيقاف تدريب الآلة.

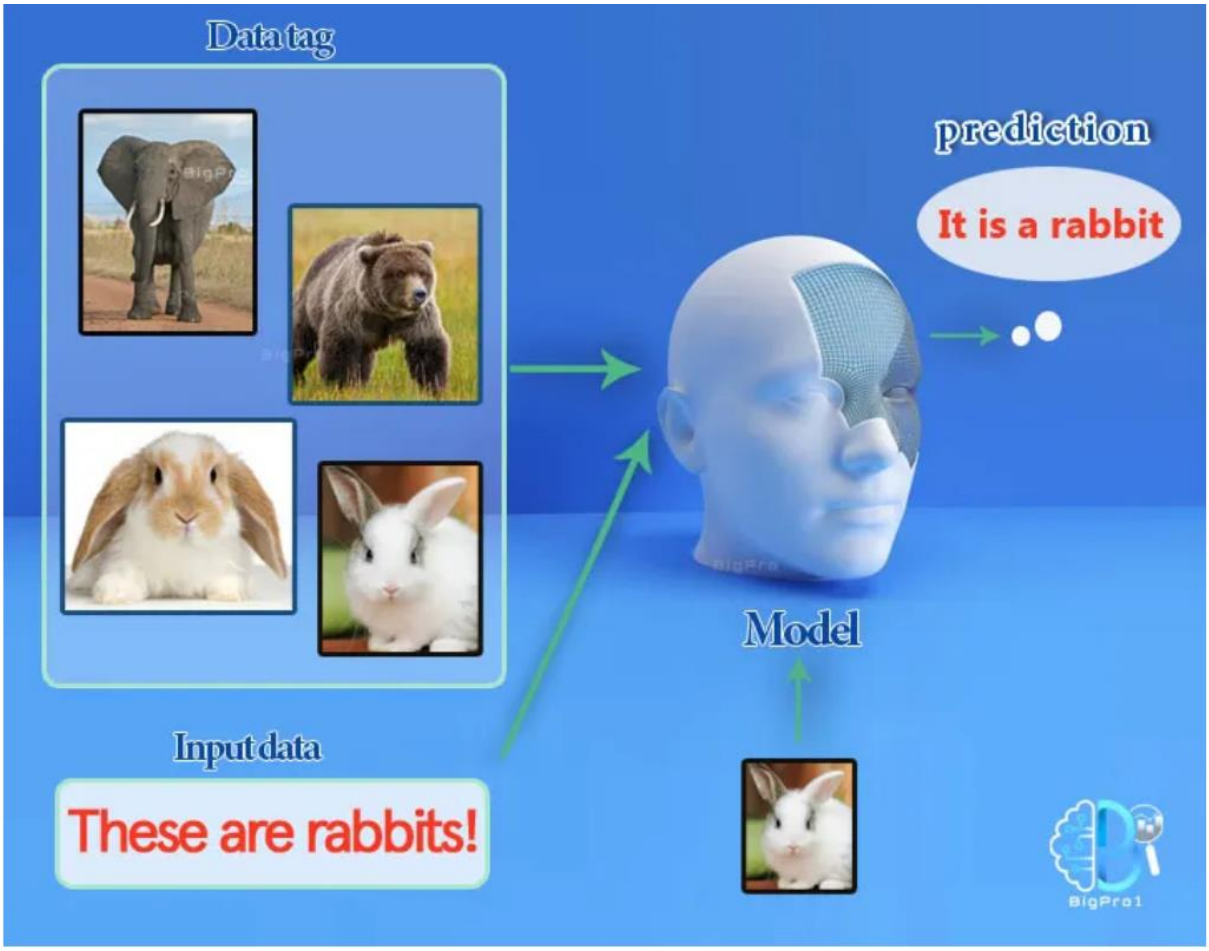

في الصورة أعلاه، درّبنا النموذج على مجموعة بيانات تسميات، مثل الأرانب والفيلة والدببة. ثم أعطينا صورة الأرنب كمدخل، وسألنا النموذج: هل هو فيل أم أرنب؟ عندها، توقع النموذج أن الصورة المدخلة هي أرنب. هذا مثال عملي على التعلم الآلي المُشرف.

فيما يلي بعض الأمثلة العملية على التعلم الآلي الخاضع للإشراف:

- التعرف على الوجوه.
- التعرف على التوقيع.
- اكتشاف العملاء.
- كشف البريد العشوائي.
- التنبؤ بالطقس.
- التنبؤ بأسعار المساكن بناءً على السعر السائد في السوق.
- توقعات أسعار الأسهم.

1- أساليب التعلم الخاضع للإشراف

هناك العديد من أساليب التعلم الخاضع للإشراف، ولكن الأكثر استخدامًا هي: التصنيف (Classification) والانحدار (Regression).

1. التصنيف (Classification):

التصنيف هو مجموعة من المهام تُنفَّذ بترتيب مُحدَّد لحل مشكلة أو اقتراح حلول جديدة. وكما هو الحال مع استخدام نظام الذكاء الاصطناعي للتعلم، فإن دور خوارزميات التصنيف المُستخدمة في التعلم الآلي هو هذا تحديدًا. فبفضلها، يُمكن للبرنامج التعلم بشكل مستقل من قواعد بيانات مُختلفة.

يَتمثل مفهوم التصنيف إذن في تصنيف العناصر المُختلفة لمجموعة البيانات إلى فئات مُختلفة. تُجمَّع هذه البيانات وفقًا لتشابهها. ونظرًا لتشابه سماتها، يُسهِّل التنبؤ بسلوكها. الهدف هو بناء نموذج يُصنف بدقة الحالات الجديدة غير المرئية ضمن الفئات الصحيحة.

على سبيل المثال، تصنيف رسائل البريد الإلكتروني كرسائل غير مرغوب فيها، والتنبؤ بما إذا كان العميل سيُغادر أم لا، أو التعرف على الأرقام المكتوبة بخط اليد.

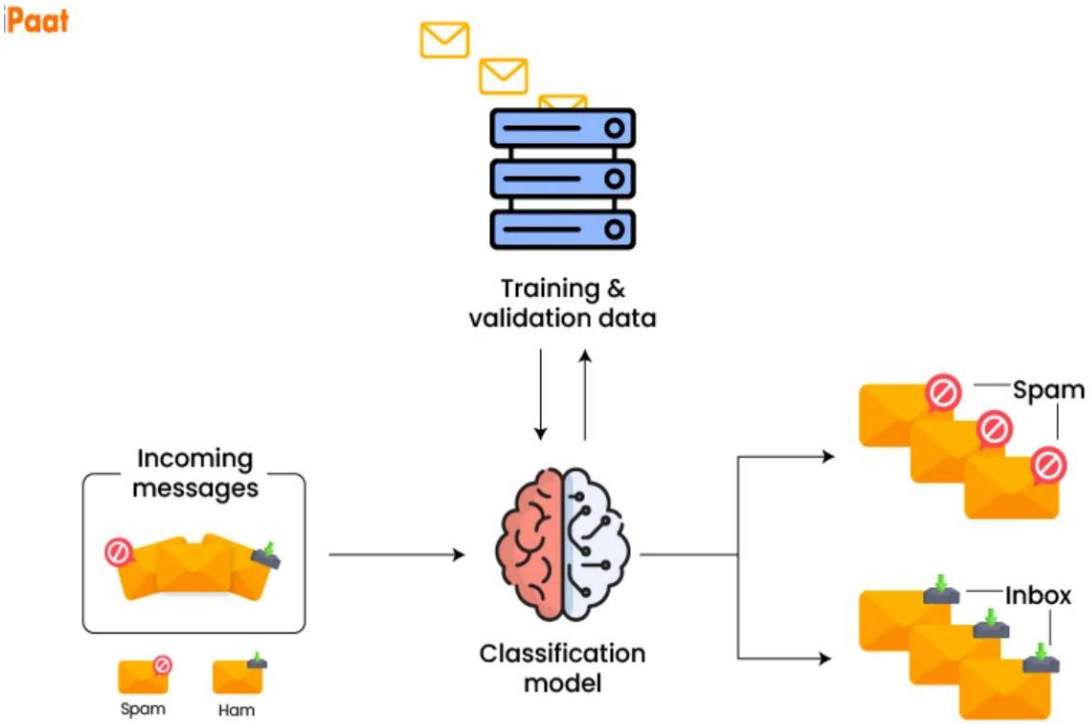

فيما يلي بعض الأسباب الرئيسية لأهمية البيانات المُصنَّفة في التعلم الخاضع للإشراف (المُراقَب):

- تدريب النموذج: تُوفِّر البيانات المُصنَّفة الحقائق الأساسية أو النتائج المعروفة التي تُشكِّل أساسًا لتدريب النموذج. من خلال تعريض النموذج لأمثلة مُصنَّفة، يُمكنه تعلُّم الأنماط والعلاقات بين سمات الإدخال والعلامات المُقابلة لها. تتضمن عملية التدريب هذه ضبط المُعاملات الداخلية للنموذج لتقليل الفرق بين مُخرجاته المُتوقعة والعلامات الحقيقية في بيانات التدريب.
- التعلم المُراقَب: يُشير مُصطلح "مُراقَب" في التعلم المُراقَب إلى وجود بيانات مُصنَّفة. باستخدام الأمثلة المُصنَّفة، يتعلم النموذج ربط أنماط إدخال مُحدَّدة بمُخرجاتها المُقابلة. يُوجِّه هذا الإشراف عملية التعلم ويُمكِّن النموذج من تعميم معرفته للتنبؤ ببيانات جديدة غير مرئية.
- التعميم: تُمكِّن البيانات المُصنَّفة نماذج التعلم الآلي من التعميم من أمثلة التدريب إلى البيانات غير المرئية. من خلال التعلم من البيانات المُصنَّفة، يُمكن للنموذج التقاط الأنماط والعلاقات الأساسية، مما يُمكِّنه من إجراء تنبؤات دقيقة على الحالات الجديدة غير المُصنَّفة. كلما كانت البيانات المصنفة أكثر تنوعًا وتمثيلًا، أصبحت قدرة النموذج على التعميم أفضل.
- التقييم وتقدير الأداء: تُعد البيانات المُصنّفة أساسية لتقييم أداء نموذج التعلم المُشرف. بمقارنة تنبؤات النموذج بالتصنيفات الصحيحة في مجموعة بيانات مُصنّفة منفصلة، يُمكن حساب مقاييس مثل الدقة، والضبط، والتذكر، ودرجة F1 لتقييم أداء النموذج. يُساعد هذا التقييم في تحديد فعالية النموذج، وتحديد مجالات التحسين، ومقارنة النماذج أو الخوارزميات المختلفة.
- التحسين التكراري: تُمكّن البيانات المُصنّفة من التحسين التكراري لنماذج التعلم الآلي. من خلال فحص تنبؤات النموذج ومقارنتها بالتصنيفات الصحيحة، يُمكن تحديد الأخطاء وتحديث معلمات النموذج لتقليلها. تُعدّ هذه العملية التكرارية للتدريب والتقييم والتحسين جانبًا أساسيًا من جوانب التعلم المُشرف، وتُوفر البيانات المُصنّفة التغذية الراجعة اللازمة للتحسين المستمر.
- التطبيقات العملية: في العديد من التطبيقات العملية، قد يكون الحصول على بيانات مُصنّفة مكلفًا ويستغرق وقتًا طويلًا. غالبًا ما يعتمد توفر البيانات المُصنّفة على الخبراء البشريين أو المعرفة المتخصصة لضمان دقة الشرح. مع ذلك، تظل البيانات المُصنّفة بالغة الأهمية لتطوير ونشر نماذج التعلم المُشرف في مختلف المجالات، بما في ذلك الرعاية الصحية، والمالية، والتسويق، والتعرف على الصور، ومعالجة اللغة الطبيعية.

2. **الانحدار (Regression):**

الانحدار هو مهمة أخرى للتعلم الخاضع للإشراف **تتضمن التنبؤ بالقيم المتصلة أو العددية** بناءً على خصائص الإدخال. الهدف من الانحدار هو بناء نموذج يُمكنه تقدير العلاقة بين المتغيرات المستقلة والمتغير التابع. على سبيل المثال، التنبؤ بأسعار المساكن بناءً على عوامل مثل الموقع، والمساحة، وعدد غرف النوم، أو التنبؤ بإيرادات المبيعات بناءً على البيانات التاريخية واتجاهات السوق.

تُستخدم لغتا البرمجة R و Python لحل مشاكل التصنيف والانحدار. يُفضل علماء البيانات هذه الطريقة في التعلّم الآلي بشدة نظرًا لمزاياها المتعددة مقارنةً بخوارزميات البيانات الأخرى. فهي سهلة التفسير، واستقرارها مُرضٍ بشكل عام، ويمكن استخدامها في مهام الانحدار أو التصنيف، مما يُتيح معالجة مجموعة واسعة من مشاكل التعلّم الآلي.

II. التعلم غير الخاضع للإشراف (unsupervised Learning)

التعلم غير الخاضع للإشراف هو أحد تقنيات تعلم الآلة، حيث يُطوَّر نموذج من مجموعة بيانات تدريب مقتصرة على المُدخلات.

يتضمن تدريب النموذج تحديد الهياكل والأنماط الموجودة في البيانات دون الحاجة إلى مخرجات مُعَلَّمة. تستخدم تطبيقات **التجميع** بشكل متكرر التعلم غير الخاضع للإشراف، مثل تجزئة العملاء، وتحليل النصوص، واكتشاف الشذوذ. يتضمن التعلم غير الخاضع للإشراف تعلم الخوارزمية بشكل مستقل.

لا تحتوي خوارزميات التعلم غير الخاضع للإشراف على متغيرات مرتبطة بالبيانات للتنبؤ بها. فبدلاً من وجود مُخرجات، تحتوي البيانات على مُدخلات فقط، وهي عبارة عن عدة متغيرات تصف البيانات. وهنا يأتي دور التجميع.

التعلم الآلي غير الخاضع للإشراف يميل إلى اكتشاف تجمعات البيانات المتشابهة، وإنشاء مجموعات. بمجرد تدريب النموذج، يمكنه تحديد أنماط مماثلة ووضع تلك البيانات في مجموعتها المناسبة. الاستخدام الشائع للتعلم الآلي غير الخاضع للإشراف هو محركات التوصيات، والتي تُستخدم في تطبيقات المستهلكين لتقديم اقتراحات "العملاء الذين اشتروا ذلك اشتروا هذا أيضًا". عند العثور على أنماط غير متشابهة، يمكن للخوارزمية تحديدها على أنها حالات شاذة، وهو أمر مفيد في اكتشاف الاحتيال.

على سبيل المثال، لنأخذ بيانات الناخبين في المجلس التشريعي لدولة مثل الجزائر. بناءً على مُدخلات مُحددة من كل ناخب (تُسمى هذه الخصائص في مصطلحات الذكاء الاصطناعي)، دع الآلة تتنبأ بأن عددًا

مُحددًا من الناخبين سيُصوّتون للحزب السياسي X، وأن عددًا مُحددًا من الآخرين سيُصوّتون للحزب Y، وهكذا. لذلك، عادةً، مع وجود مجموعة ضخمة من نقاط البيانات X، نسأل الآلة: "ماذا يُمكنك أن تُخبرني عن X؟". أو يُمكن أن يكون سؤالًا مثل: "ما هي أفضل خمس مجموعات يُمكننا تكوينها من X؟" أو قد يكون سؤالًا مثل: "ما هي الخصائص الثلاث الأكثر شيوعًا في X؟"

تُستخدم نماذج التعلم غير الخاضع للإشراف لثلاث مهام رئيسية: **التجميع، الترابط، وتقليل الأبعاد**. سنُعرّف أدناه كل طريقة تعلم، ونُسلّط الضوء على الخوارزميات والأساليب الشائعة لإجرائها بفعالية.

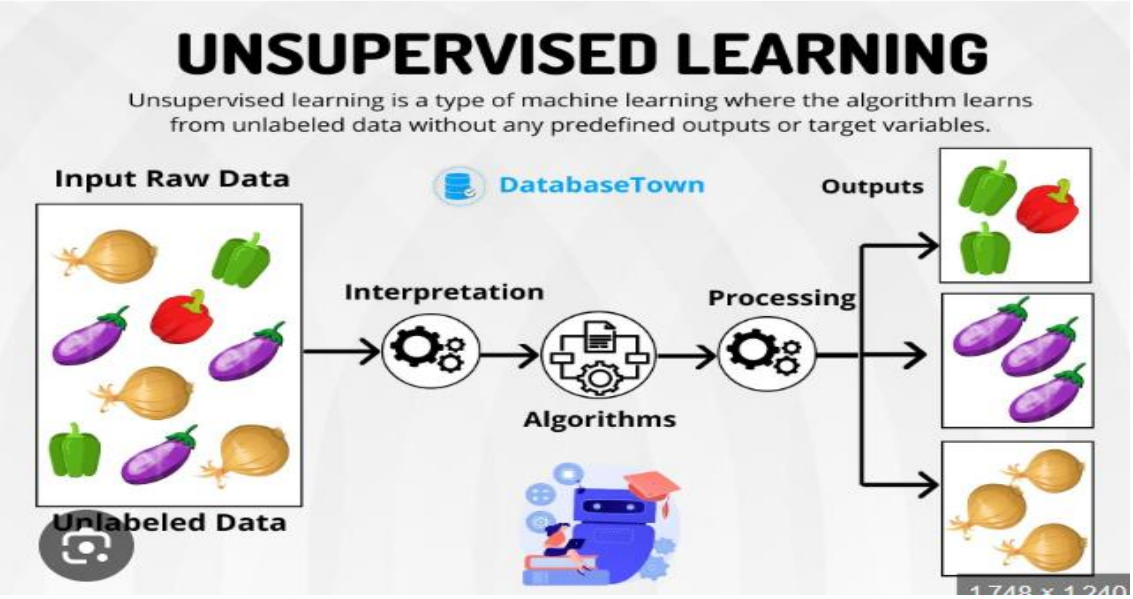

1. **التجميع (Clustering)**

التجميع هو تقنية لاستكشاف البيانات الخام غير المُصنّفة وتقسيمها إلى مجموعات (أو عناقيد) بناءً على أوجه التشابه أو الاختلاف بينها. يُستخدم في تطبيقات مُتنوعة، بما في ذلك تجزئة العملاء، وكشف الاحتيال، وتحليل الصور. تُقسّم خوارزميات التجميع البيانات إلى مجموعات طبيعية من خلال إيجاد هياكل أو أنماط مُتشابهة في البيانات غير المُصنّفة.

يُعد التجميع أحد أشهر أساليب التعلم الآلي غير المُشرف. تُستخدم عدة أنواع من خوارزميات التعلم غير المُشرف للتجميع: الحصري، والمتداخل، والهرمي، والاحتمالي.

- **التجميع الحصري**: تُجمّع البيانات بحيث لا تتواجد نفس نقطة البيانات إلا في عنقود واحد. ويُعرف هذا أيضًا بالتجميع "الصارم". ومن الأمثلة الشائعة على التجميع الحصري خوارزمية التجميع بمتوسطk ، التي تُقسّم نقاط البيانات إلى عدد K من العناقيد يُحدده المستخدم.
- **التجميع المتداخل**: تُجمّع البيانات بحيث تتواجد نفس نقطة البيانات في عنقودين أو أكثر بدرجات عضوية متفاوتة. ويُعرف هذا أيضًا بالتجميع "الناعم."
- **التجميع الهرمي**: تُقسّم البيانات إلى عناقيد مميزة بناءً على أوجه التشابه بينها، ثم تُدمج هذه العناقيد وتُنظّم بشكل متكرر بناءً على علاقاتها الهرمية. هناك نوعان رئيسيان من التجميع الهرمي: التجميع التجميعي والتجميع التقسيمي. وتُسمى هذه الطريقة أيضًا التحليل الهرمي للتجميع (HAC).
- **التجميع الاحتمالي**: تُجمّع البيانات في عناقيد بناءً على احتمالية انتماء كل نقطة بيانات إلى كل عنقود. يختلف هذا النهج عن الطرق الأخرى، التي تقوم بتجميع نقاط البيانات على أساس أوجه التشابه بينها وبين غيرها في مجموعة.

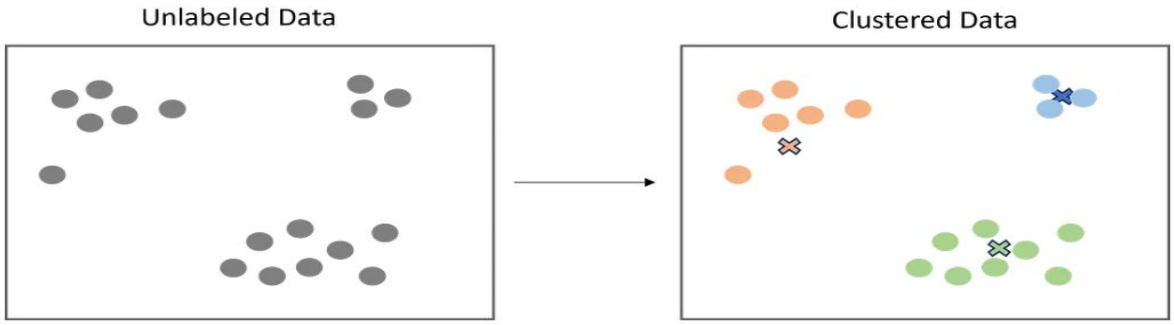

2. الترابط (Association):

استخراج قواعد الارتباط هو نهج قائم على القواعد يكشف عن علاقات مثيرة للاهتمام بين نقاط البيانات في مجموعات البيانات الكبيرة. تبحث خوارزميات التعلم غير المُشرف عن ارتباطات (أو قواعد) "إذا-فإن" المتكررة لتحديد الارتباطات والتزامن في البيانات، بالإضافة إلى الروابط المختلفة بين كائنات البيانات.

يُستخدم هذا النهج غالبًا لتحليل عربات التسوق أو مجموعات بيانات المعاملات لتمثيل مدى تكرار شراء سلع معينة معًا. تحدد هذه الخوارزميات أنماط شراء العملاء والعلاقات الخفية سابقًا بين المنتجات، مما يُساعد في توجيه محركات التوصية أو فرص البيع المتبادل الأخرى. قد تكون على دراية بهذه القواعد من قسمي "المشتريات المتكررة معًا" و"الأشخاص الذين اشتروا هذا المنتج اشتروا أيضًا" في متجرك الإلكتروني المفضل.

تُستخدم قواعد الارتباط أيضًا غالبًا لتنظيم مجموعات البيانات الطبية لأغراض التشخيص السريري. يُمكن أن يُساعد التعلم الآلي غير المُشرف وقواعد الارتباط الأطباء على تحديد احتمالية تشخيص مُحدد من خلال مُقارنة العلاقات بين الأعراض في الحالات السابقة.

تُستخدم خوارزميات "أبريوري" عادةً لتعلم قواعد الارتباط لتحديد مجموعات العناصر أو مجموعات العناصر المترابطة. ومع ذلك، تُستخدم أيضًا أنواع أخرى من الخوارزميات، مثل "إكلات" أو "FP-Growth".

3. تقليل الأبعاد (Minimization Distances)

يُعد تقليل الأبعاد أسلوبًا للتعلم غير المُشرف، يُقلل عدد السمات، أو الأبعاد، في مجموعة البيانات. في التعلم الآلي، يُفضل عمومًا توفير أكبر قدر ممكن من البيانات. ومع ذلك، قد يُعقّد هذا أيضًا عملية تصوّر البيانات.

يُستخرج تقليل الأبعاد السمات المهمة من مجموعة البيانات، مما يُقلل عدد السمات غير ذات الصلة أو العشوائية الموجودة. تستخدم هذه الطريقة خوارزميات تحليل المكونات الرئيسية (PCA) وتحليل القيمة المفردة (SVD) لتقليل عدد مُدخلات البيانات دون المساس بسلامة خصائص البيانات الأصلية.

مقارنة بين التعلم الخاضع للإشراف والتعلم غير الخاضع للإشراف

العامل	التعلم الخاضع للإشراف	التعلم غير الخاضع للإشراف
طبيعة البيانات	بيانات مصنفة (مع تسميات)	بيانات غير مصنفة
آلية التعلم	النموذج يتعلم من أمثلة واضحة	النموذج يكتشف الأنماط والعلاقات بنفسه
الاستخدامات	التصنيف والتنبؤ	تجميع البيانات، وتقليل الأبعاد
أمثلة على الخوارزميات	الانحدار، شجرة القرار، آلة المتجهات الداعمة (SVM)	التجميع العنقودي(K-means) ، الشبكات العصبية التلافيفية(Autoencoders)

III. التعلم شبه الخاضع للإشراف (Semi-supervised Learning)

صُمم التعلم شبه ا شبه الخاضع للإشراف (SSL) خصيصًا لمجالات التطبيق التي تكثر فيها البيانات غير المُصنّفة، مثل معالجة الصور، وجمع المعلومات، وعلم المعلومات الحيوية.

تقع تقنية SSL في منتصف الطريق بين التعلم الخاضع للإشراف وغير الخاضع للإشراف ، مما يعني أن مجموعة البيانات مُقسّمة إلى بيانات مُصنّفة وأخرى غير مُصنّفة.

يعالج مشكلة عدم وجود بيانات مصنفة كافية لتدريب نموذج بشكل كامل. على سبيل المثال، قد تكون لديك مجموعات بيانات تدريب كبيرة ولكنك لا ترغب في تحمّل الوقت والتكلفة اللازمين لتصنيف المجموعة

بأكملها. باستخدام مزيج من الطرق الخاضعة للإشراف وغير الخاضعة للإشراف، يمكنك غالبًا تحقيق نموذج مدرَّب بالكامل. تبدأ عملية التدريب مثل التعلم الخاضع للإشراف، باستخدام البيانات المصنفة للحصول على نتائج أوليّة ووضع إرشادات للخوارزمية. عند استنفاد البيانات المصنفة، يتم إعطاء النموذج شبه المدرَّب مجموعات البيانات غير المصنفة. إنه يستخدم التدريب الذي تلقاه وينظر إلى البيانات غير المصنفة، بهدف الإضافة إلى مجموعة البيانات المصنفة. إذا استطاع النموذج العثور على تصنيف مناسب لعينة بدرجة عالية من التأكد، تُضاف تلك العينة إلى البيانات المصنفة. تبدأ عملية التعلم مرة أخرى، ولكن الآن بمجموعة أكبر من العينات المصنفة. من خلال التكرار، يتم تصنيف المزيد من العينات بما يسمى غالبًا التصنيفات الزائفة، ويمكن تحسين النموذج بشكل أكبر.

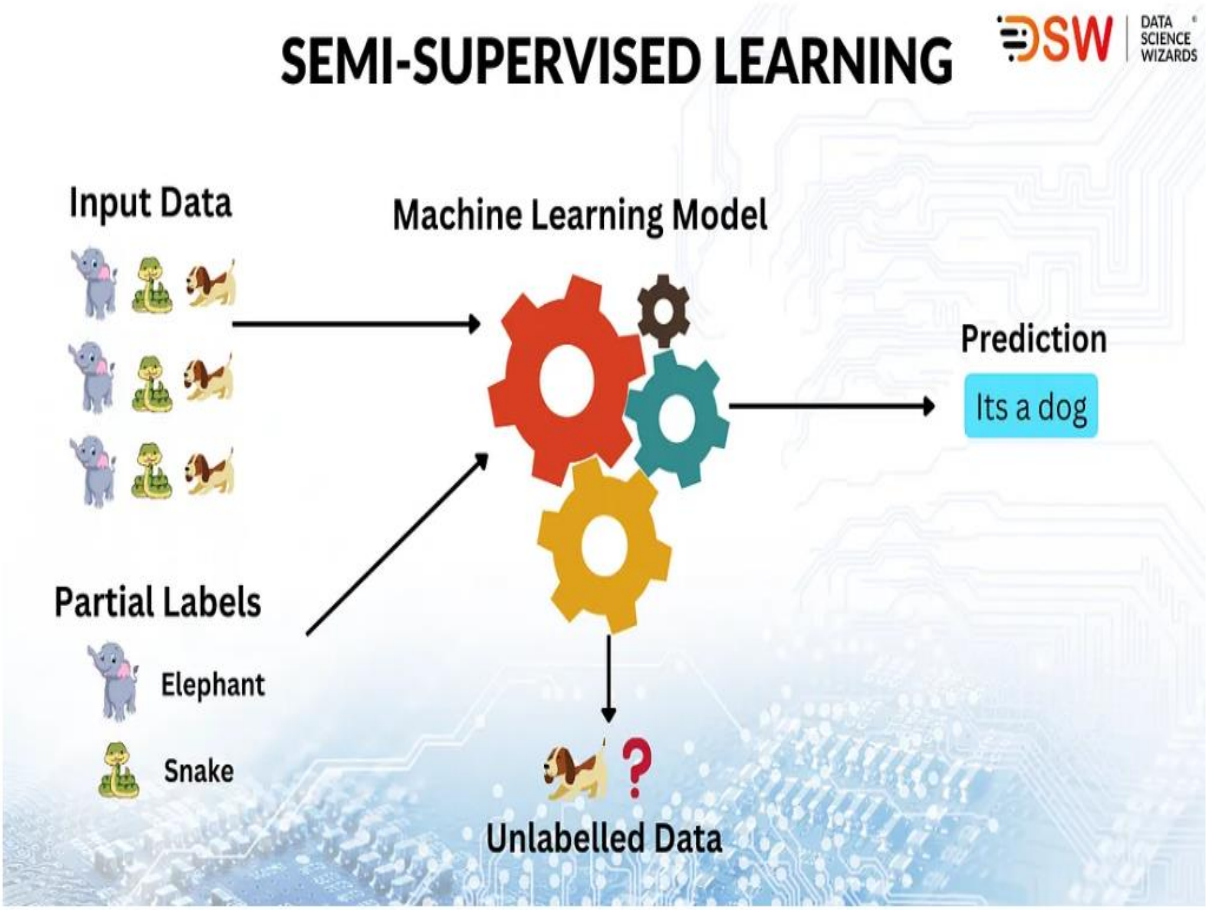

IV. التعلم المُعزز (Renforcement Learning)

التعلم المعزز هو النموذج الرابع في التعلم الآلي. في التعلم الخاضع للإشراف، يُعطى الكمبيوتر مفتاح الإجابة ثم يتعلم من خلال تحديد العلاقات بين جميع النتائج الصحيحة. لا يقدم نموذج التعلم المعزز مفاتيح الإجابة ولكنه يسرد السلوكيات والقواعد والنتائج المحتملة المسموح بها.

عندما تكون النتيجة المتوقعة للخوارزمية ثابتة أو ثنائية، يمكن لأجهزة الكمبيوتر أن تتعلم بالقدوة. عندما قد يختلف الناتج المتوقع، يجب على النظام أن يتعلم من خلال الخبرة والمكافأة. في نماذج التعلم المعزز، تكون "المكافأة" رقمية ومدمجة في الخوارزمية كشيء تجمعه الآلة.

في كثير من النواحي، هذا النموذج يشبه شخصًا يتعلم لعب الشطرنج. سيكون من المستحيل أن نظهر لهذا الرجل كل خطوة ممكنة. وبدلاً من ذلك، عليك أن تشرح لها القواعد حتى تتمكن من تحسين مواهبها من خلال الممارسة. ستحصل على حوافز للفوز باللعبة وأخذ قطع خصمها. للتعلم المعزز عدة استخدامات، بما في ذلك التسعير الآلي لمشتري إعلانات الإنترنت، وإنشاء ألعاب الكمبيوتر، والتداول في سوق الأوراق المالية عالي المخاطر.

مثل التعلم الآلي غير الخاضع للإشراف، يستخدم مجموعات بيانات غير مصنفة ويسمح للخوارزميات بتقييم البيانات. ومع ذلك، يختلف التعلم المعزز في أنه يعمل لتحقيق هدف محدد بدلاً من استكشاف البيانات لاكتشاف أي أنماط قد تكون موجودة. مع وضع هدف في الاعتبار، تتقدم الخوارزمية في عملية التجربة والخطأ. تتلقى كل خطوة تعليقات إيجابية أو سلبية أو محايدة، والتي تستخدمها الخوارزمية لصقل عملية صنع القرار الشاملة الخاصة بها. يمكن لخوارزميات التعلم المعزز أن تعمل على مستوى كلي نحو هدف المشروع، حتى لو كان ذلك يعني التعامل مع عواقب سلبية قصيرة الأجل. بهذه الطريقة، يتعامل التعلم المعزز مع مواقف أكثر تعقيدًا وديناميكية من الطرق الأخرى لأنه يسمح لسياق هدف المشروع بالتأثير على المخاطر في الخيارات. يُعد تعليم الكمبيوتر لعب الشطرنج مثالاً جيدًا. الهدف العام هو الفوز باللعبة، ولكن ذلك قد يتطلب التضحية بقطَع مع تقدم اللعبة.

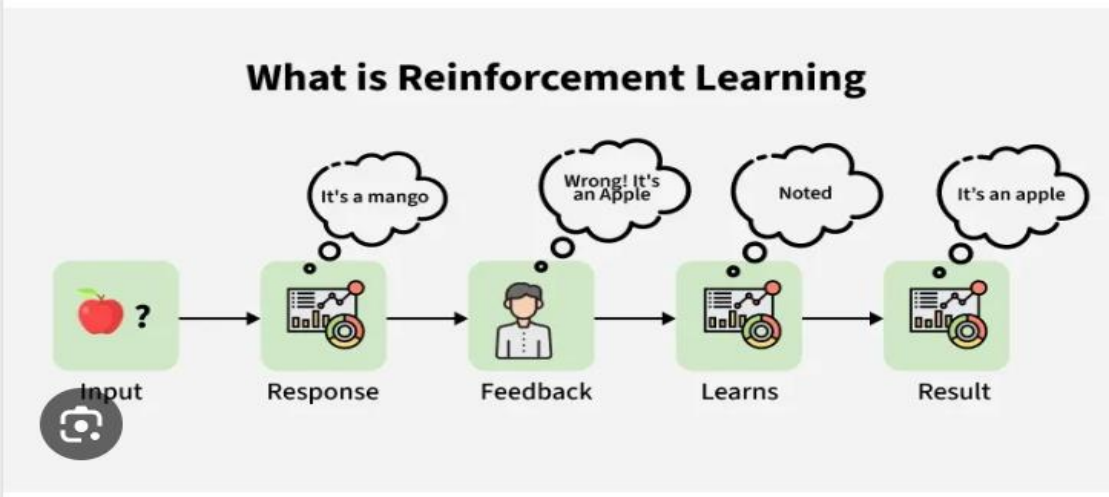

ما هو النهج الأفضل الذي يناسب احتياجاتك؟ يعتمد اختيار النهج الخاضع للإشراف أو إحدى الطرق الثلاث الأخرى عادةً على بنية وحجم بياناتك، والميزانية والساعات التي يمكن تخصيصها للتدريب، وحالة الاستخدام التي تريد تطبيق النموذج النهائي عليها. قد يكون التغاضي عن اقتراح بلوزة لتتناسب مع تنورة غير ذي أهمية. أما تفويت ورم فله عواقب وخيمة.